

# Kelime Temsil Yöntemlerinin Hedef Tabanlı Duygu Analizine Etkisi

*Araştırma Makalesi/Research Article*

 Mesut POLATGİL<sup>1</sup>,  Murat Fatih TUNA<sup>2</sup>,  Oğuz KAYNAR<sup>2</sup>

<sup>1</sup>Sarıışla Uygulamalı Bilimler Yüksekokulu, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye

<sup>2</sup>Yönetim Bilişim Sistemleri, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye

[mesutpolatgil@cumhuriyet.edu.tr](mailto:mesutpolatgil@cumhuriyet.edu.tr), [mftuna@cumhuriyet.edu.tr](mailto:mftuna@cumhuriyet.edu.tr), [okaynar@cumhuriyet.edu.tr](mailto:okaynar@cumhuriyet.edu.tr)

(Geliş/Received:10.05.2022; Kabul/Accepted:21.09.2022)

DOI: 10.17671/gazibtd.1114901

**Özet**—Klasik duygu analizi yöntemlerinden farklı olarak hedef tabanlı duygu analizi (HTDA), birden fazla kategorinin olduğu karmaşık yapıdaki çevrimiçi tüketici geribildirimlerini değerlendirmede daha başarılı bir performans ortaya koyabilmektedir. Nitekim bir platformda yer alan tüketici geri bildirimleri bir ürüne ilişkin birden farklı hedefe atfedilebilmektedir ve standart duygu analizleri bu geribildirimleri analiz etmede yetersiz kalmaktadır. Literatürdeki gelişmeler gözden geçirildiğinde, HDTA çalışmalarının, duygu analizine odaklanan diğer çalışmalar içinde oldukça popüler olduğu anlaşılmaktadır. SemEval ABSA-2016 yarışmasında, HTDA için 8 farklı dilde veri setleri yayınlanmış ve ekipler duygu analizi için yarışmışlardır. Yarışmada hedef terim, kategori ve duygu sınıfı tespit etmek gibi farklı alt görevler bulunmaktadır. Bu alt görevlerin içindekilerden biri, hedef terimin tespit edilmesidir. Türkçe dili için HTDA çalışmaları oldukça sınırlıdır. Farklı diller ve farklı kelime temsil yöntemleri kullanan çalışmalar vardır. SemEval Absa 2016 yarışması Türkçe veri seti için kelime temsil yöntemlerinin etkisini inceleyen çalışma bulunmamaktadır. Bu çalışma, müşteri yorumlarındaki hedef terimlerin tespitinde farklı kelime temsil yöntemlerinin başarısının incelenmesi amacıyla gerçekleştirilmiştir. Word2Vec, Glove ve Fasttext kelime temsil yöntemleri analiz kapsamında incelenmiş ve hedef terimi en başarılı tespit edebilen yöntemin Fasttext kelime temsil yöntemi olduğu görülmüştür. Çalışmada ayrıca F-1 sınıflandırma ölçütü açısından %77 başarı oranı ile Türkçe veri seti için literatürdeki en yüksek sınıflandırma başarısı elde edilmiştir.

**Anahtar Kelimeler**— hedef tabanlı duygu analizi, hedef terim, kelime temsil yöntemleri, müşteri geribildirimleri, Türkçe metinler, Word2Vec, Glove, Fasttext.

## The Effect of Word Representation Methods on Aspect-Based Sentiment Analysis

**Abstract**—Unlike classical sentiment analysis methods, Aspect-Based Sentiment Analysis (ABSA) can demonstrate a more successful performance in evaluating complex online consumer feedbacks including more than one category. As a matter of fact, consumer feedbacks on a platform can be referred to more than one aspect regarding a product, and standard sentiment analysis method is insufficient to analyse these comments. When the developments in the literature are reviewed, it is understood that HDTA studies are very popular among other studies focusing on sentiment analysis. In the SemEval ABSA-2016 competition, datasets were published in 8 different languages for HTDA and the teams competed for sentiment analysis. There are different subtasks in the competition, determining sub-categories such as aspect term, category and sentiment class. One of these subtasks is to determine the aspect term. HTDA studies for Turkish language are quite limited. There are studies using different languages and different word representation methods. There is no study examining the effect of word representation methods for the Turkish data set of SemEval Absa 2016 competition. This study was carried out to examine the success of different word representation methods in identifying aspect terms in customer comments. This study was carried out with the aim of examining the success of different word representation methods in identifying target terms in customer comments. Word2Vec, Glove and Fasttext word representation methods were examined within the scope of the analysis and it was seen that the method that could detect the aspect term most successfully was the Fasttext word representation method. The highest classification success for Turkish dataset in the literature with a success rate of 77% in terms of the F-1 score was also achieved in the study.

**Keywords**— aspect based sentiment analysis, aspect term, word representation methods, consumer feedbacks, Turkish texts, Word2Vec, Glove, Fasttext

## 1. GİRİŞ (INTRODUCTION)

Web 2.0 ve Endüstri 4.0 kapsamında yaşanan değişimler, kullanıcı temelinde değişen içeriğin üretildiği bir yeni bir dünya oluşturmuştur. Eski dünyadan farklı olarak, sadece seçkin bir zümre değil artık her zümreden insanın kendini ifade edebildiği ve milyonlarca insana ulaşabildiği bir ortama geçilmiştir [1]. Bu ortam bireylerin duygularını ve ruh hallerini özgürce ve kendilerince ifade edebildiği bir mecaz halini almıştır. Hatta normal hayatlarında gerçek duygu ve düşüncelerini paylaşamayan kişilerin, sosyal medya üzerinden kendilerini rahatça ifade edebilmeleri, sosyal medya ve diğer ortamları, bireylerin düşünce, tutum ve davranışlarının ölçülmesinde daha gerçekçi sonuçlar verebilecek bir veri kaynağına dönüştürmüştür [2]. Dolayısıyla burada üretilen içerikler ve paylaşılan görüşler, işletmelerin tutmuş oldukları büyük verilere eklenerek işletmelerin karar verme süreçlerine katılmaya başlanmıştır [3].

Zaltman ve Zaltman [4], tüketicilerden gelen geri bildirimlerin altını kurcalamanın, onları daha net anlamada yardımcı olacağını vurgulamıştır. Günümüzde sosyal medya, bunu gerçekleştirebilmenin en az maliyetli yolu olarak düşünülebilir. Ayrıca Westerman vd. [5], sosyal medyanın sağladığı verilerin, tüketici ve işletme üzerine yapılan çalışmalar açısından güvenilir bir veri kaynağı oluşturduğunu saptamışlardır. İşletmeler (kâr amacı gütsün ya da gütmesin) ürün ve süreçlerle ilgili yorum ve görüşleri internet ve sosyal medya ortamından toplamakta, bunları inceleyerek elde ettikleri bilgileri pazarlama ve diğer işletme birimlerine yönelik strateji oluşturmada bir argüman olarak kullanmaktadır [6]. İletişim imkânlarının karşılıklı hale gelmesi, tüketicilerin anlık geribildirimlerini firmaya iletebilecekleri koşulların sağlanmasına neden olmuştur. Gerek fiziki ürünlerin gerekse hizmetlerin tüketiciyle buluşturulmasından hemen sonra tüketiciler sosyal medya ve internet platformlarını kullanarak ürün ya da hizmete ilişkin geribildirimlerini paylaşmaktadır. Dahası yapılan paylaşımlar, sosyal medyadaki yoğun etkileşimden dolayı hızlı bir şekilde yayılabilmektedir. İşletmeler bu viral etkinin ve satışlara olan katkısının farkında olduğundan hem tüketicilerin geribildirimlerini hızlı işleme hem de işlenen geribildirimlerden elde edilen göstergeleri hızlı bir şekilde potansiyel müşterilerle paylaşılabilirliği amaçlamaktadır [7]. Sedanter eğilime sahip [8] ve zaman yönetiminde zorlanan [9] günümüz tüketicisi, yoğun şekilde kullandığı internet ortamını daha yaygın etkileşimli bir pazar haline getirmektedir. Ayrıca artan çevrimiçi firma-müşteri etkileşiminden doğan sözel müşteri verilerinin anlık analiz edilmesinin gerekliliği, herhangi bir ürün ya da hizmeti ve bunların alt bileşenlerine ilişkin müşteri görüşlerini özet bir şekilde ortaya koyan uzman sistemlere olan ihtiyacı artırmaktadır [10].

Müşteri odaklı yaklaşımın bir sonucu olarak işletmelerin sürdürülebilirlik düzeyleri ve rekabet güçleri, müşterileri ile olan iletişimlerine ve onlardan gelen geri bildirimleri değerlendirme kapasitelerine bağlıdır [11]. Bu kapasite

aynı zamanda bir ürün ya da hizmetin kalitesine müşteri dokunuşunu sağlamanın da bir yoludur [12]. Dolayısıyla günümüz tüketicileri, sosyal medya ve internet platformlarıyla inşa sürecine katıldığı ürün, hizmet ve bilgiye daha yoğun ilgi göstermektedir [13]. Bu noktada Tuna vd. [14] bu geri bildirimleri bilgisayar ve teknoloji destekli süreçlerle hızlı bir şekilde analiz edebilme kapasitesini müşteri sadakatini sağlamada etkin bir yol olarak değerlendirmişlerdir. Bu durum işletmeler tarafından da bilindiğinden işletmelerin sosyal medya gönderilerine gösterdikleri önemi artırmıştır. Nitekim ürün ya hizmetleriyle alakalı geri bildirim alan ve bunları doğru şekilde değerlendiren kurumlar güçlü sayılmaktadır [15]. Bugün Uber\*, Amazon\*\*, TripAdvisor\*\*\* firmaları, ilgili alanda faaliyet gösteren işletme ve satıcılara ilişkin yorumlarla sırasıyla 100 milyon\*, 300 milyon\*\* ve 450 milyon\*\*\* civarı kullanıcının yoğun iletişim ve ilişki kurmasına imkân tanımaktadır [16].

Bu konjonktürde işletmelerin metinsel ifadelerden oluşan bu verileri olabildiğince hızlı ve detaylı bir şekilde analiz edebilmesi gerekmektedir ki insan gücü ile günümüz işletmelerinde bu ilave maliyet ve zaman kaybı anlamına gelmektedir [1]. Ayrıca yorumların nicel olmayışı ve sayısının fazlalığı, klasik analiz metodlarının etkinliğini azaltmaktadır. Bahsedilen durumların gerektirdiği yöntemlerden biri duygu analizidir. Diğer bir adı fikir madenciliği olan duygu analizi, metinsel verinin içindeki ifadenin tamamının ya da bir kısmının içerdiği duygunun metin analizi, doğal dil işleme, hesaplamalı dilbilimle işlenmesidir [17]. Duygu analizi yapılırken belirli bir alana özgü ve içerisinde farklı unsurları konu edinen metin derlemi (corpus) kullanılmakta, derlem içerisinde bir test ve eğitim veri seti oluşturulmaktadır. Analiz sonucunda metinsel ifadeler temelde pozitif ve negatif olarak ayrıştırılabilmektedir. Oluşturulan bu veri seti genellikle makine öğrenmesi teknikleriyle bir bütün doküman olarak (document-based) analiz edilebildiği gibi konu tabanlı (topic-based), cümle tabanlı (sentence-based) ve hedef tabanlı (aspect-based) olarak da incelenebilmektedir. Bu çalışmaya konu olan hedef tabanlı duygu analizinin ilk alt görevi olan hedef terimin tespitidir. Al-Smadi vd. [18]'ne göre bu analiz tipinde bir metinsel verinin temasında yer alan farklı hedef terimlere yönelik duygu yönelimi ve şiddetine odaklanılmaktadır.

Hedef tabanlı duygu analizinde hedef terimin neyle ilgili olduğunun anlaşılması, başka bir ifadenin içerdiği duygunun hangi kapsamda olduğunun tespit edilmesiyle mümkün olabilmektedir [19]. İnce taneli yöntemlerden biri olan bu analize ilişkin Wang vd. [20] tarafından verilen örnek, duygulardaki hedeflerin belirlenmesinin anlaşılır bir örneğini oluşturmaktadır. Buna göre, bir restoran yorumunda geçen “şehirdeki en hızlı teslim zamanlarından birine sahip olduklarını söylemek zorundayım” şeklinde bir ifade hedef terimin “teslim zamanları”, fikir teriminin ise “en hızlı” olduğu anlaşılabilir. Nitekim teslim zamanları ifadesi en hızlı sıfatıyla nitelendirilmektedir [21].

## 2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Literatür incelendiğinde, ilk duygu analizi çalışmasının Pang vd. [22] tarafından yapıldığı görülmektedir. Klasik duygu analizi kullanarak yapılan çalışma ve uygulamaların; metin analizinde yeterli derinliğe inemediği [20], ince taneli duygu analizi gerçekleştirebilecek kapasiteye sahip olmadığı [23] ve bütün bir metnin içerisindeki baskın duygu sınıfını belirlemek üzerine odaklandığı [1] görülmektedir. Ayrıca bir ürün ya da hizmetin farklılaştığı esas noktaları belirlemede klasik duygu analizi türlerinin yeterli olmadığı savı üzerinde görüş birliği sağlandığı görülmektedir [15], [24].

Hedef tabanlı duygu analizine temel teşkil eden çalışmalar, hedef derecelemesi [25] ve hedef tarama [26] konularıyla başlamıştır. Hedef tabanlı duygu analizine yapılan devam çalışmalarının; elektronik ürünlere [27], filmlere [28], otellere [14], [29] ve restoranlara [30] yönelik yorumları kapsayacak şekilde geliştirildiği görülmektedir. Literatür incelendiğinde, hedef tabanlı duygu analizine ilişkin çalışmalara 2014 yılı itibarıyla rastlanmaktadır. Bu alandaki çalışmalardan birinde Blinov ve Kotelnikov [31], dizüstü bilgisayar ile restoranlara ilişkin İngilizce yorumlardan oluşturulan iki farklı veri seti üzerinde çalışmışlardır. Semeval-2014 yarışmasının verilerini kullandıkları çalışmalarında, hedef terim çıkarımı ve hedef terim duygu polaritesine ilişkin yöntem önerisinde bulunmuşlardır. Bu çalışmanın sonucunda kategori tespitinde %50,51; kategori polarite tespitinde dizüstü bilgisayar ve restoran veri setleri için sırasıyla %37,38 ve %43,34 şeklindeki F-1 değerlerine ulaşmışlardır.

Literatürde çeşitli dillerde hazırlanan veri setleri üzerinde yapılmış çalışmalar bulunmaktadır [18, 32]. Ayrıca LSTM tabanlı farklı kelime temsil yöntemlerini kullanan çalışmada bulunmaktadır [16]. Bununla birlikte bu çalışmada Türkçe veri setleri üzerinde çalışılacağından ötürü, Türkçe veri setleri üzerinde hedef tabanlı duygu analizi yürüten çalışmalara odaklanılacaktır. Farklı dillerle birlikte Türkçe veri setinin de birlikte konu edinildiği bir çalışmada Pontiki vd. [33], SemEval-2016 yarışmasının 5 numaralı görevini yerine getirmek için çok katımlı bir hedef tabanlı duygu analizi çalışması yürütmüşlerdir. Çalışmalarında İngilizce, Arapça, Çince, Hollandaca, Fransızca, Rusça, İspanyolca ve Türkçe dillerindeki restoran ve otel veri setleri üzerinde çalışmışlardır. Hedef tabanlı duygu terimlerini çıkardıkları çalışmanın sonucunda, kullandıkları dillerden Türkçe dili için ulaştıkları en yüksek F1 performans ölçüm değerinin %41,86 olduğu ortaya konulmuştur.

Kama vd. [34], online arama motorunu kullanarak frekans tabanlı nitelik çıkarma performansını artıracak denetimsiz bir model kullanarak hedef tabanlı duygu analizi gerçekleştirmişlerdir. Donanımhaber isimli teknoloji forumunu kullandıkları çalışmalarında önerdikleri web arama tabanlı nitelik çıkarma (WSBFE) yönteminin hedef terim çıkarmada performansın F1 değerinin %69,79 olduğunu iddia etmişlerdir.

ABSA 2016 yarışmasında sunulan Türkçe restoran veri setinin kullanıldığı bir çalışmada Çetin ve Eryiğit [1]; hedef kategori belirleme, hedef terim belirleme, hedef kategoriyle terimi aynı anda belirleme ve duygu sınıfı belirleme şeklinde yarışmaya açılan dört görevi gerçekleştirmeyi amaçlamışlardır. Bu dört görev için sırasıyla %66,7; %53,2; %46,7 ve %76,1 F1 değerleri elde edilmiştir. Çalışmada kullanılan duygu analizi bir lineer sınıflandırma ile gerçekleştirilmiştir.

İstatistiksel, linguistik ve kural tabanlı yaklaşımları (gizli dirichlet ataması "LDA", c-değeri, WSBFE) bir arada kullandıkları çalışmalarında Bayraktar vd. [35], ABSA 2016'da yayınlanan restoran verilerini kullanmışlardır. Çalışmanın sonucunda performans elde etmenin amaçlandığı hedef terim çıkarımı ve hedef-duygu eşleşmesine ilişkin F1 değerleri sırasıyla %56,28 ve %52,05 olarak hesaplanmıştır.

Özyurt ve Akçayol [36], yapmış oldukları çalışmalarında ürünlere ilişkin hedef terimlerin çıkarılmasında ve ürün terimlerinin çıkarılmasında hedef tabanlı duygu analizi kullanmışlardır. Semeval-2016 yarışmasındaki görevlerin tamamlanması için cümle segmentasyonu ve LDA yöntemlerinin birlikte kullanıldığı çalışmada, hedef terimlerin çıkarılması ve ürün terimlerinin çıkarılması görevlerine ilişkin F1 ölçüm değerleri sırasıyla %62,25 ve %82,39 olarak hesaplanmıştır.

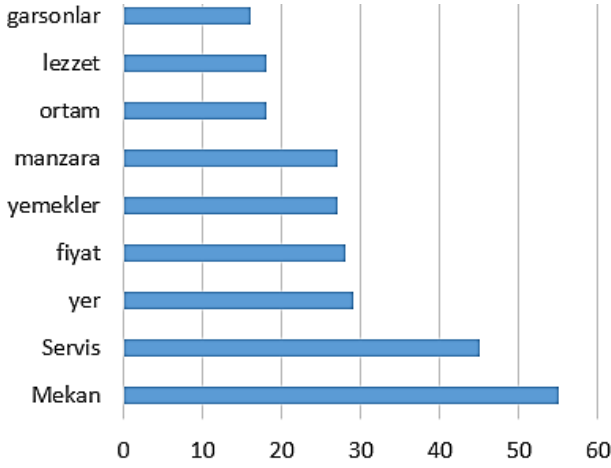
Salur ve Aydın [37], Güneydoğu'daki turistik merkezlere ilişkin ziyaretçi yorumlarına hedef tabanlı duygu analizi uygulamışlardır. Turistik merkezlerin hedef terimlerini çıkartıldığı çalışmada Türkçe etiketlenmiş bir veri setini de kullanıcıların erişimine sunmuşlardır. TF-IDF ve LDA yöntemlerini kullandıkları çalışmalarında F-1 ölçüm değerini 0,5931 olarak hesaplamışlardır.

Salur vd. [15], ABSA 2016 yarışmasında sunulan Türkçe restoran yorumlarını kullandıkları çalışmalarında yorumlarından hedef terimlerini çıkarmak için istatistiksel (TF-IDF), konu modelleme (LDA ve NMF) ve kural-tabanlı denetimsiz yöntemleri bir arada kullanan bir sınıflandırma yaklaşımı önerilmiştir. Önerdikleri 'ensemble' yaklaşımının %61,08'lik bir F1 değerine ulaştığını ileri sürmüşlerdir.

## 3. YÖNTEM (METHOD)

### 3.1. Veri seti (Data Set)

Çalışmada SemEval ABSA 2016 kapsamında oluşturulmuş ve birçok çalışmada da kullanılmış olan Türkçe Restoran yorumlarını içeren bir veri seti bulunmaktadır. Bu veri setinde 1415 tane cümle bulunmaktadır. Bu cümlelerden 148 cümle bir duygu durumunu içermemektedir. Veri setinde yer alan cümlelerde hedef terim barındırmayan ('Null') cümleler değerlendirmeye alınmamıştır. Veri setinde en çok yer alan hedef terimler Şekil 1'de verilmiştir.



Şekil 1. Veri setinde en çok geçen hedef terimler [15]  
(Most common target terms in the dataset)

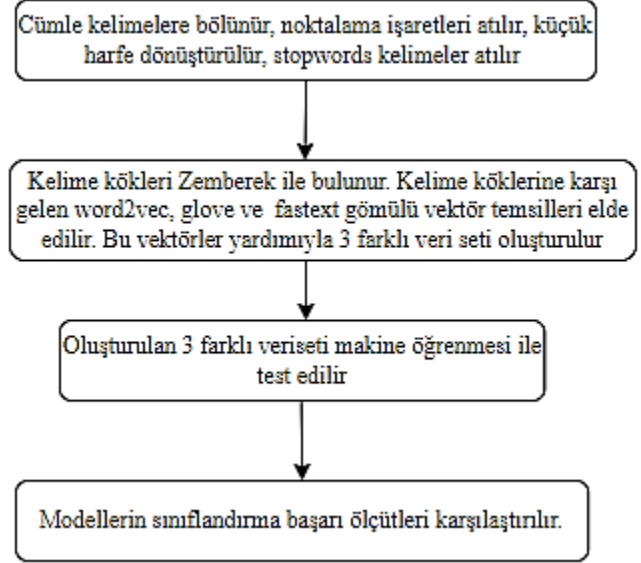
Şekil 1’de en çok geçen hedef terimlerin mekân, servis, yer ve fiyatlar olduğu görülmektedir. Restoran ile ilgili olabilecek ifadelerin hedef terim olarak öne çıktığı görülmektedir.

### 3.2. Önerilen Yöntem (Proposed Method)

Bu çalışmada ABSA 2016 yarışması kapsamında görevlerden birisi olan hedef terimin tespit edilmesi için bir model önerilmiştir. SemEval ABSA yarışmasında 3 temel görev olduğu belirtilmiştir. Bunlar; Sentence-level ABSA, Text-level ABSA ve Out-of-domain ABSA olarak belirlenmiştir. Sentence-level ABSA görevi 3 alt bölüme ayrılmıştır. Bunlar; hedef terimin belirlenmesi, hedef kategorinin belirlenmesi ve duygu sınıfının belirlenmesi. Burada tespit edilen tüm tahminler cümle düzeyinde olmaktadır. Text-level ABSA kategorisinde ise analiz bir yorum üzerinden yapılmaktadır ki bu yorum genellikle birden fazla cümle içerebilir. Out-of-domain ABSA kategorisinde ise ekiplere daha önce hiç görmedikleri bir alanda eğitim verisi sağlanmadan sistemlerini test etme imkânı verilmektedir. Yarışma sonuçları değerlendirilmesinde 2 aşama söz konusudur. İlk aşamada hedef terim, hedef kategori çiftinin bulunması, diğer aşamada ise duygu sınıfının bulunması yer almaktadır. Sonuçlar F-1 sınıflandırma ölçütüne göre değerlendirilmektedir.

Önerilen modelde kelimenin kendisi ve kök bilgisi cümleden elde edilerek önceden eğitilmiş modellerden elde edilen gömülü kelime temsil vektörleri ile desteklenmesi sonucunda hedef terimin yüksek başarı ile tespit edilebileceği hipotezi test edilmek istenmiştir. Özetle bu araştırma, ABSA 2016 yarışmasında cümle-düzeyi (sentence-level) ABSA kategorisinin hedef terim ifadesinin tespit edilmesi alt görevine odaklanmıştır.

Bu hipotez önerilirken daha önce aynı veri seti üzerinde yapılan hedef terim tespiti çalışmalarında önerilen modeller incelenmiştir [1, 37]. Bu çalışmalarda kelime kök bilgisi, morfolojik analiz, kelimenin kendisi, komşu kelimeler, bağıllık ayrıştırıcı, LDA analizi ve kural tabanlı olmak üzere farklı yaklaşımlar önerilmiştir. Fakat önerilen yöntemler hem veri setinden çekilecek özellikler bakımından karmaşık hem de bu verilerin elde edilmesi için kullanılacak sistem ve programlar açısından zahmetlidir. Bu çalışmada ise sadece kelime kök bilgisinden elde edilecek gömülü vektör temsilleri yardımıyla böyle bir zorlu görevin başarılabileceğini göstermektedir.

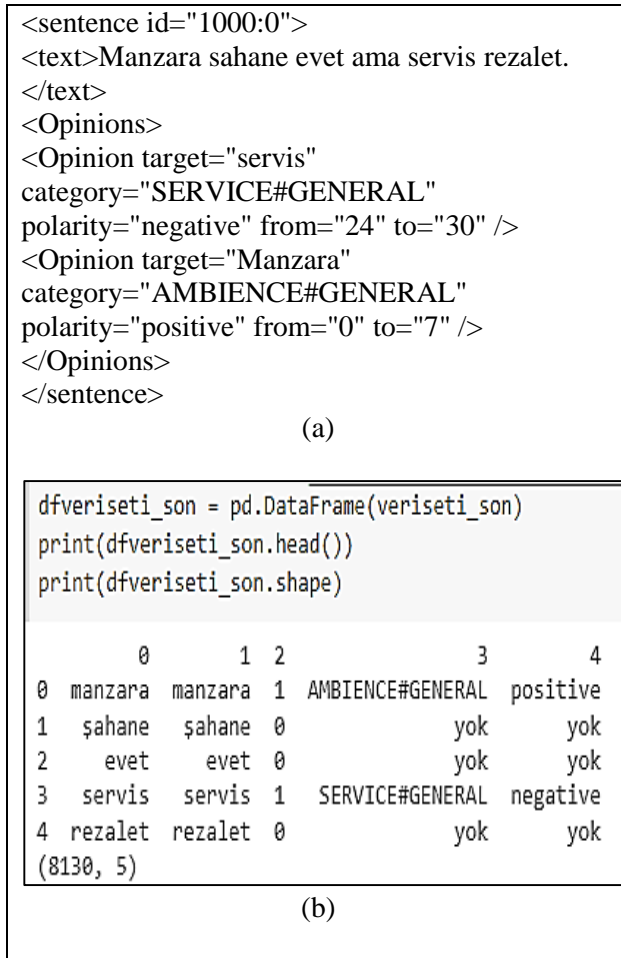


Şekil 2. Çalışmada önerilen işlem adımları (Suggested steps in the study)

Şekil 2’de verildiği gibi hedef terimi elde etmek için önerilen model öncelikle ilgili cümlelerin kelimelere bölünmesi, sonrasında küçük harfe dönüştürülmesi, ardından noktalama ve durak(stopwords) kelimelerin atılması gibi bir takım metin ön işleme adımlarının uygulanması ile başlamaktadır.

Daha sonra her bir kelimenin kökü Zemberek Kütüphanesi yardımı ile elde edilerek bulunur. Zemberek kütüphanesi ile veri setindeki bir örnek cümle için kök bulma işlemi Şekil 3’de verilmiştir.

Kelime kökleri elde edildikten sonra her kelimenin Word2Vec, Glove ve Fasttext yöntemleri ile daha önce hazır olarak eğitilmiş modellerden sırasıyla 400, 300 ve 300 boyutlu gömülü vektör temsil modelleri elde edilmiştir. Bu sayısal vektörler veri seti için giriş bilgisini oluştururken, ilgili terimin hedef terim olup olmadığı bilgisi ise çıkış bilgisini oluşturmaktadır. Oluşturulan veri setinden ilk cümle için örnek Şekil 3’de verilmiştir.



Şekil 3. ABSA veri setinde bulunan örnek cümle. (a). Xml formatındaki veri (b). Python ve Zemberek ile işlenmesi (Example sentence found in the ABSA dataset. (a). Data in xml format (b). Processing with Python and Zemberek)

Tablo 1. Veri setinin yapısı örnek cümle gösterimi (Structure of the dataset example sentence representation)

Kelime	Kelime Vektörü	Hedef terim
Manzara	(0.43, 0.47, 0.01 .....0.22)	1
Şahane	(0.12, 0.41, 0.59 .....0.45)	0
Evet	(0.15, 0.52, 0.07 .....0.74)	0
Servis	(0.59, 0.48, 0.02 .....0.36)	1
Rezalet	(0.92, 0.14, 0.85 .....0.62)	0

Word2Vec kelime temsillerini elde etmek için daha önceden eğitilmiş bir modelden yararlanılmıştır. Türkçe

Wikipedia derlemi kullanılarak eğitilen modelde Cbow yöntemi tercih edilmiş, kelime vektör uzunluğu 400, pencere boyutu ise 5 olarak belirlenmiştir [38]. Glove yöntemi ile oluşturulan diğer model ise 21 GB boyutundaki Commoncrawl verileri ile eğitilerek, 300 uzunluğundaki kelime vektörleri ile oluşturulmuştur [39]. Fasttext vektör temsillerini elde etmek için daha önce Grave vd tarafından yapılmış bir çalışmada kullanılan ve Türkçe için eğitilmiş 300 uzunluklu kelime vektörüne sahip bir modelden yararlanılmıştır [40].

#### 4. BULGULAR (RESULTS)


Makine öğrenmesi algoritmaları uygulanmadan veri setine 5 fold çapraz geçerlilik uygulanmıştır. Veri seti 5 parçaya bölünerek 4 parçasıyla eğitim 1 parçasıyla test işlemi gerçekleştirilmiştir. Bu işlem her seferinde test için kullanılan birim değiştirilerek 5 kere tekrar edilmiş ve elde edilen test skorlarının ortalaması modelin genel performansı olarak hesaplanmıştır. Böylelikle veri setini eğitim ve test kümelerine ayırma işlemi sırasında doğacak avantajlı durumların önüne geçilerek model performansını gösteren metriklerin daha güvenilir bir şekilde elde edilmesi sağlanmıştır. Tablo 2'de belirtilen makine öğrenme yöntemleri kullanılarak analizler gerçekleştirilmiş, F-1 metrikleri yardımıyla algoritmaların başarımları kıyaslanmıştır. Tablo 2'de görüleceği üzere model performansları kullanılan algoritmadan bağımsız olarak birbirine yakın F-1 skoru değerleri elde edilmiştir. Bu nedenle F-1 skoru en yüksek olan lojistik regresyon yönteminin kullanılmasına karar verilmiş analiz detayları bu yönetime göre verilmiştir.

Lojistik Regresyon yöntemi kullanırken verilerin dengesiz bir dağılım göstermesi sebebi ile 'class\_weight' parametresi kullanılarak bu durumun öğrenme sırasında göz önünde bulundurulması sağlanmıştır.

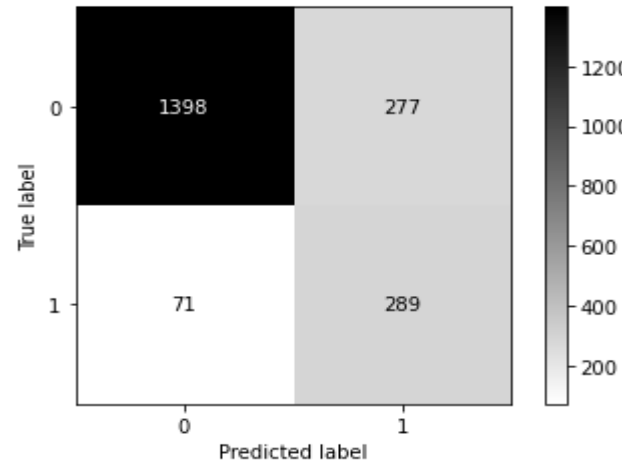
Tablo 2. Algoritmaların F-1 başarı ölçütleri (F-1 scores criteria of algorithms)

	Word2Vec	Glove	Fasttext
KNN	72	74	75
Lojistik Reg.	73	75	<b>77</b>
Destek Vektör	72	73	75
Rassal Orman	74	74	76


Lojistik Regresyon yönteminin eğitim ve test kümesi üzerindeki karmaşıklık matrisleri Şekil 7-9'da verilmiştir.




(a)



(a)





(b)



(b)

Şekil 4. Word2Vec veri seti hedef terim tespiti karmaşıklık matrisi (a) eğitim aşaması , (b) test aşaması (Word2Vec dataset aspect term detection confusion matrix (a) training phase , (b) testing phase)

Şekil 5. Glove veri seti hedef terim tespiti karmaşıklık matrisi (a) eğitim aşaması , (b) test aşaması (Glove dataset aspect term detection confusion matrix (a) training phase , (b) testing phase)



Şekil 6. Fasttextveri seti için hedef terim tespiti karmaşıklık matrisi (a) eğitim aşaması , (b) test aşaması (Aspect term detection confusion matrix for fasttext data set (a) training phase, (b) testing phase)

Tablo 3 Word2Vec test veri kümesi sınıflandırma ölçütleri (Word2Vec test dataset classification scores)

	Sınıflar		Ortalama
	0	1	
Kesinlik	0.92	0.52	0.72
Duyarlılık	0.87	0.66	0.765
F-1	0.90	0.58	0.74

Tablo 4. Glove test veri kümesi sınıflandırma ölçütleri (Glove test dataset classification scores)




	Sınıflar		Ortalama
	0	1	
Kesinlik	0.96	0.48	0.72
Duyarlılık	0.81	0.82	0.815
F-1	0.88	0.61	0.745

Tablo 5. Fasttext test veri kümesi sınıflandırma ölçütleri (Fasttext test dataset classification criteria)

	Sınıflar		Ortalama
	0	1	
Kesinlik	0.96	0.51	0.735
Duyarlılık	0.82	0.86	0.84
F-1	0.90	0.64	0.77

ABSA yarışmasında F-1 ölçütü kullanıldığı için çalışma sonuçları da bu ölçüt üzerinden değerlendirilmekte birlikte diğer ölçütler de Tablo 3-5'de verilmiştir.

Tablo 3-5'de verilen değerler kullanılarak modelin test kümesi üzerinde F-1 ölçütü bakımından sırasıyla Word2Vec için ortalama %73, Glove için ortalama %75 ve Fasttext için ortalama %77 başarı elde edilmiştir. Sonuçlardan da anlaşılacağı üzere en iyi başarı 0.77 F-1 skoru ile Fasttext vektör temsili kullanılması durumunda elde edilmiştir. Çalışmada kullanılan veri setinin dengesiz dağılımı göz önünde bulundurularak çalışma sonuçlarının güvenilirliğinin tam olarak yansıtılabilmesi için ROC (Receiver operating characteristic) eğrisi çizdirilerek eğri altında kalan alan AUC (Area under curve) değerleri de hesaplanmıştır.



Şekil 7. ROC eğrisi grafiği (a). Word2Vec (b). Glove (c). Fasttext (ROC curve graph (a). Word2Vec (b). Glove (c). fasttext)



Şekil 7’de verilen ROC eğrileri önerilen her üç kelime temsil yönteminin hedef terim tespitinde başarılı bir şekilde kullanılabileceğini göstermektedir. ROC eğrisi altında kalan alanı temsil eden AUC değerleri sırasıyla Word2Vec için 0.83, Glove için 0.86 ve Fasttext için ise 0.88 olarak bulunmuştur.

Çalışmanın son aşamada ise 3 farklı kelime vektörü yönteminden elde edilen vektörler birleştirilerek hedef terim tespiti yapılmıştır. Her üç yöntemden elde edilen kelime temsillerinin birleştirilmesiyle 1000 boyutlu bir kelime vektörü kullanılmıştır. Fakat farklı kelime temsil vektörlerinin birleştirilmesinin sınıflandırma başarısı üzerinde bir iyileştirme sağlamadığı tespit edilmiştir.

Çalışma kapsamında her ne kadar hedef terim tespiti problemi ele alınmış olsa da kelime vektörlerinin hedef kategori ve duygu sınıfını belirlenmesi problemleri de test edilmiştir. Fakat elde edilen sonuçlar literatür de kullanılan yöntemlere oranla daha yüksek bir başarı sağlayamamıştır. Bu durum kategori sınıflarındaki örnek sayısının dengesiz olmasından kaynaklanmaktadır. Bazı kategoriler çok sayıda örnek cümle içerirken bazı kategorilerdeki örnek cümle sayısı oldukça sınırlıdır.

## 5. TARTIŞMA (DISCUSSION)

Bu çalışmada ABSA yarışmasında oluşturulmuş olan Türkçe restoran veri kümesi üzerinde hedef terim tespiti için yeni bir model önerilmiştir. Önerilen modelde kelimenin sadece kökü kullanılarak hedef terimi başarılı bir şekilde tespit edebileceği hipotezi araştırılmıştır. Aynı veri kümesi üzerinde daha önce farklı yöntemlerle yapılan çalışma sonuçları Tablo 6’da verilerek karşılaştırılmıştır.

Tablo 6. Literatürdeki hedef terim tespiti yapılan çalışmalar ile kıyaslama (Comparison with studies on aspect term detection in the literature)

Kaynak	Yöntem	F1 (%)
[33]	Sözlük tabanlı	41,86
[34]	WSBFE	69,79
[1]	CRF	53,12
[35]	Kural-Tabanlı Yaklaşım	56,28
[36]	SS-LDA	62,25
[37]	TF-IDF+LDA	59,31
[15]	Ensemble Yaklaşımı	61,08
<b>Önerilen yöntem</b>	<b>Lojistik Regresyon</b>	<b>77</b>

Tablo 6 incelendiği zaman hedef terim tespitine yönelik Türkçe Restoran veri seti üzerinde farklı çalışmaların yapıldığı görülmektedir. SemEval ABSA tarafından hedef terim tespiti için temel bir yöntem zaten önerilmiş ve yarışma ekiplerinden daha başarılı sonuçlar beklenmiştir. ABSA tarafından önerilen temel modelde kategoriler için bir sözlük oluşturulmuştur. Kategorilerde geçen terimler bu sözlük içine konulmuş ve bir terim ilgili kategori

sözlüğünde yer alıyorsa hedef terim olarak sınıflandırılmıştır. Bu yöntemin başarısı ise %41.8 olarak belirtilmiştir. Yarışmada Türkçe verisi ile ilgili olarak başka başvuru olmamıştır. Bu çalışma kapsamında önerilen modelin hedef terim tespit etmede ABSA temel yöntemine göre oldukça başarılı olduğu görülmektedir.

Hedef terim tespit edilmesi için literatürde farklı yöntemler [1,33-35] ve farklı yöntemlerin birlikte kullanıldığı ensemble yöntemler [15,36,37] önerilmiştir. Önerilen yöntemlerin sınıflandırma başarısında özellikle ABSA temel yöntemine göre iyileştirmeler yapıldığı gösterilmiştir. Bu çalışmalar temel yöntemlere göre başarı göstermiş olsalar da bu çalışmada önerilen kelimelerin farklı gömülü temsillerinin hedef terim tespitinde kullanımı diğer yöntemlerden daha başarılı sonuçlar elde etmiştir. Hedef terim tespitinde önceden eğitilmiş gömülü vektör temsillerinin kullanılması sınıflandırma algoritmasından bağımsız olarak literatürde önerilen diğer yöntemlerden daha üstün performans göstermiştir. Sonuç olarak gömülü temsil yöntemlerinin hedef terim belirlemede sınıflama algoritmalarından bağımsız olarak iyi bir öznelik belirleyici olarak kullanılabileceğini göstermektedir.

## 6. SONUÇ (CONCLUSION)

Müşterilerden gelen geribildirimlerin analizi, onların zihinlerinde bir ürün ya da hizmete yönelik oluşacak algıların temel belirleyicileri konumuna yükselmiştir. Hedef tabanlı duygu analizi, sadece bir ürün ya da hizmete değil aynı zamanda ürün ya da hizmetin alt boyutlarına yönelik kullanıcı yorumlarını kategori bazında resmetmeyi sağlayan bir araçtır. Bu analizi etkin kullanmayı başaran firmalar, daha önceki tüketicilerin deneyimlerini çarpıcı biçimde potansiyel müşterilerin bilgisine sunmanın alternatif bir yoluna da sahip olmaktadır. Nitekim günümüz pazarlama çabaları büyük ölçüde müşterilerden gelen geri bildirimlere dayandığı gibi, bu geri bildirimler müşterilerin karar verme süreçlerinde vazgeçilmez bir referans noktası haline almıştır. Deneysel pazarlamanın bir getirisi olarak kabul edilebilecek bu durum, tüketicilerden gelen sözel geri bildirimlerin içerdiği duyguları tespit etmenin işletmeler açısından neden elzem olduğuna işaret etmektedir. Bu durum, tüketicinin ziyade kullanıcının deneyimine ve deneyim sonrasındaki geri bildirimlere üretici ya da satıcının anlatılarından daha fazla güvendiğine de işaret etmektedir. Dolayısıyla çalışmanın, işletmelerin alt hizmet kalemlerine ilişkin müşteri duygularının sınıflandırılmasında ve ilgili kalemlere yönelik özet duygu gösterimlerinde gerek işletme sahiplerine gerekse bu alanda akademik çalışma yapan araştırmacılara efektif ve yüksek performanslı yöntem teşkil edeceği düşünülmektedir. İlerleyen çalışmalarda hedef terimin tespit edilmesine ek olarak, kategori ve duygu sınıfının ayrı ayrı ve birlikte tespit edilebileceği farklı gömülü kelime temsil yöntemlerini tek tek ya da hibrit şekilde kullanan yeni modeller gerçekleştirilebilir ve bu modellerin başarımları farklı veri setleri üzerinde test edilebilir.



**KAYNAKLAR (REFERENCES)**

- [1] F. S. Çetin, G. Eryiğit, “Türkçe Hedef Tabanlı Duygu Analizi İçin Alt Görevlerin İncelenmesi – Hedef Terim, Hedef Kategori ve Duygu Sınıfı Belirleme”, *Bilişim Teknolojileri Dergisi*, 11(1), 43–56, 2018.
- [2] O. Kaynar, Y. Görmez, M. Yıldız, A. Albayrak, “Makine öğrenmesi yöntemleri ile Duygu Analizi”, **International Artificial Intelligence and Data Processing Symposium (IDAP’16)**, Malatya, 234–241, September 17-18, 2016.
- [3] Z. Khan, T. Vorley, “Big data Text Analytics: An Enabler of Knowledge Management”, *Journal of Knowledge Management*, 21(1), 18–34, 2017.
- [4] G. Zaltman, L. H. Zaltman, **Marketing Metaphoria: What Deep Metaphors Reveal About the Minds of Consumers (1st edition)**, Harvard Business Review Press, Boston, 2008.
- [5] D. Westerman, P. R. Spence, B. Van Der Heide, “Social Media as Information Source: Recency of Updates and Credibility of Information”, *Journal of Computer-Mediated Communication*, 19(2), 171–183, 2014.
- [6] V. Ahuja, Y. Medury, “Corporate Blogs as e-CRM Tools – Building Consumer Engagement through Content Management”, *Journal of Database Marketing & Customer Strategy Management*, 17(2), 91–105, 2010.
- [7] P.-Y. Chen, S. Wu, J. Yoon, “The Impact of Online Recommendations and Consumer Feedback on Sales”, in **ICIS 2004 Proceedings**, 58, 2004.
- [8] A. A. Thorp, G. N. Healy, E. Winkler, B. K. Clark, P. A. Gardliner, N. Owen, D. W. Dunstan, “Prolonged Sedentary Time and Physical Activity in Workplace and Non-Work Contexts: A Cross-Sectional Study of Office, Customer Service and Call Centre Employees”, *International Journal of Behavioral Nutrition and Physical Activity*, 9(128), 1–9, 2012.
- [9] J. Cotte, S. Ratneshwar, D. G. Mick, “The Times of Their Lives: Phenomenological and Metaphorical Characteristics of Consumer Timestyles”, *Journal of Consumer Research*, 31(2), 333–345, 2004.
- [10] T. Y. Lee, E. T. Bradlow, “Automated Marketing Research Using Online Customer Reviews”, *Journal of Marketing Research*, 48(5), 881–894, 2011.
- [11] S. A. Bhat, M. A. Darzi, “Service, People and Customer Orientation: A Capability View to CRM and Sustainable Competitive Advantage”, *Vision*, 22(2), 163–173, 2018.
- [12] A. Stelzer, F. Englert, S. Hörold, C. Mayas, “Improving Service Quality in Public Transportation Systems Using Automated Customer Feedback”, *Transportation Research Part E: Logistics and Transportation Review*, 89, 259–271, 2016.
- [13] V. Barger, J. W. Peltier, D. E. Schultz, “Social Media and Consumer Engagement: A Review and Research Agenda”, *Journal of Research in Interactive Marketing*, 10(4), 268–287, 2016.
- [14] M. F. Tuna, O. Kaynar, M. Ş. Akdoğan, “Otellere İlişkin Çevrimiçi Geribildirimlerin Makine Öğrenmesi Yöntemleriyle Duygu Analizi”, *İşletme Araştırmaları Dergisi*, 13(3), 2232–2241, 2021.
- [15] M. U. Salur, İ. Aydın, M. Jamous, “An ensemble approach for aspect term extraction in Turkish texts”, *Pamukkale University Journal of Engineering Sciences, Ahead of Print*, 2022.
- [16] Ł. Augustyniak, T. Kajdanowicz, P. Kazienko, “Comprehensive Analysis of Aspect Term Extraction Methods using Various Text Embeddings”, arXiv:1909.04917 [cs], 2020.
- [17] S. G. Barbounaki, K. Gourounti, A. Sarantaki, “Advances of Sentiment Analysis Applications in Obstetrics/Gynecology and Midwifery”, *Materia Socio Medica*, 33(3), 225–230, 2021.
- [18] M. Al-Smadi, O. Qawasmeh, M. Al-Ayyoub, Y. Jararweh, B. Gupta, “Deep Recurrent Neural Network vs. Support Vector Machine for Aspect-Based Sentiment Analysis of Arabic Hotels’ Reviews”, *Journal of Computational Science*, 27, 386–393, 2018.
- [19] B. Liu, “Sentiment Analysis and Opinion Mining”, *Synthesis Lectures on Human Language Technologies*, 5(1), 1–167, 2012.
- [20] Y. Wang, M. Huang, X. Zhu, L. Zhao, “Attention-Based LSTM for Aspect-Level Sentiment Classification”, **Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing**, Austin (Texas):Association for Computational Linguistics, 606–615.
- [21] W. Wang, S. J. Pan, D. Dahlmeier, X. Xiao, “Recursive Neural Conditional Random Fields for Aspect-based Sentiment Analysis”, **Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing**, Austin (Texas):Association for Computational Linguistics, 616–626.
- [22] B. Pang, L. Lee, S. Vaithyanathan, “Thumbs up? Sentiment Classification using Machine Learning Techniques”, **Proceedings of the 2002 Conference on Empirical Methods in Natural Language Processing (EMNLP 2002)**, Pennsylvania(Philadelphia): Association for Computational Linguistics, 79–86, 2002.
- [23] T. T. Thet, J.-C. Na, C. S. G. Khoo, “Aspect-Based Sentiment Analysis of Movie Reviews on Discussion Boards”, *Journal of Information Science*, 36(6), 823–848, 2010.
- [24] S. Brody, N. Elhadad, “An Unsupervised Aspect-Sentiment Model for Online Reviews”, Program No: HLT-NAACL, 2010. URL: [https://openreview.net/forum?id=HJ-8d7-\\_bH](https://openreview.net/forum?id=HJ-8d7-_bH), 04.04.2022.
- [25] I. Titov, R. McDonald, “A Joint Model of Text and Aspect Ratings for Sentiment Summarization”, **Proceedings of ACL-08: HLT**, Columbus(Ohio): Association for Computational Linguistics, 308–316, 2008.
- [26] J. Zhu, H. Wang, B. K. Tsou, M. Zhu, “Multi-Aspect Opinion Polling from Textual Reviews”, **Proceedings of the 18th ACM Conference on Information and Knowledge Management**, New York: ACM Digital Library, 1799–1802, 2009.
- [27] J. Wang, B. Xu, Y. Zu, “Deep Learning for Aspect-Based Sentiment Analysis”, **International Conference on Machine Learning and Intelligent Systems Engineering (MLISE)**, Chongqing: IEEE, 267–271, 2021.
- [28] D. Anand, D. Naorem, “Semi-Supervised Aspect Based Sentiment Analysis for Movies Using Review Filtering”, *Procedia Computer Science*, 84, 86–93, 2016.
- [29] T. Tran, H. Ba, V.-N. Huynh, “Measuring Hotel Review Sentiment: An Aspect-Based Sentiment Analysis Approach”, In **Integrated Uncertainty in Knowledge Modelling and Decision Making**, Cham, 393–405, 2019.

- [30] D. Ekawati, M. L. Khodra, “Aspect-Based Sentiment Analysis for Indonesian Restaurant Reviews”, **International Conference on Advanced Informatics, Concepts, Theory, and Applications (ICAICTA-17)**, Kuta: IEEE, 1–6, 2017.
- [31] P. Blinov, E. Kotelnikov, “Blinov: Distributed Representations of Words for Aspect-Based Sentiment Analysis at SemEval 2014”, **Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)**, Dublin: Association for Computational Linguistics, 140–144, 2014.
- [32] W. Wang, G. Tan, H. Wang, “Cross-Domain Comparison of Algorithm Performance in Extracting Aspect-Based Opinions from Chinese Online Reviews”, *International Journal of Machine Learning & Cybernetics*, 8(3), 1053–1070, 2017.
- [33] M. Pontiki, D. Galanis, H. Papageorgiou, I. Androustopoulos, S. Manandhar, M. Al-Smadi, M. Al-Ayyoub, Y. Zhao, B. Qin, O. D. Clercq, V. Hoste, M. Apidianaki, X. Tannier, N. Loukachevitch, E. Kotelnikov, N. Bel, S. M. Jiménez-Zafra, G. Eryiğit, “SemEval-2016 Task 5: Aspect Based Sentiment Analysis”, **Proceedings of the 10th International Workshop on Semantic Evaluation (SemEval-2016)**, San Diego (California): Association for Computational Linguistics, 19–30, 2016.
- [34] B. Kama, M. Ozturk, P. Karagoz, I. H. Toroslu, O. Ozay, “A Web Search Enhanced Feature Extraction Method for Aspect-Based Sentiment Analysis for Turkish Informal Texts”, **In Big Data Analytics and Knowledge Discovery**, Cham, 225–238, 2016.
- [35] K. Bayraktar, U. Yavanoglu, A. Ozbilen, “A Rule-Based Holistic Approach for Turkish Aspect-Based Sentiment Analysis”, **IEEE International Conference on Big Data (Big Data)**, Los Angeles: IEEE, 2154–2158, 2019.
- [36] B. Ozyurt, M. A. Akcayol, “A New Topic Modeling Based Approach for Aspect Extraction in Aspect Based Sentiment Analysis: SS-LDA”, *Expert Systems with Applications*, 168, 114231, 2021.
- [37] M. U. Salur, İ. Aydın, “An Annotated Turkish Aspect Based Sentiment Analysis Corpus for Smart Tourism”, **2021 Innovations in Intelligent Systems and Applications Conference (ASYU)**, Elazığ: IEEE 1–6, 2021.
- [38] Internet: A. Köksal, Github, <https://github.com/akoksal/Turkish-Word2Vec>, 15.02.2022.
- [39] O. Çiftçi, GitHub, <https://github.com/inzva/Turkish-GloVe>, 15.02.2022.
- [40] E. Grave, P. Bojanowski, P. Gupta, A. Joulin, T. Mikolov, “Learning Word Vectors for 157 Languages”, **Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018)**, Miyazaki, European Language Resources Association (ELRA), 3483–3487, 2018.